

BAB II

LANDASAN TEORI

Penyusunan tugas akhir ini membahas tentang kebangkrutan, laporan keuangan, rasio keuangan, *LVQ 2.1*. Berikut menjelaskan teori yang mendukung penelitian ini.

2.1 Kebangkrutan Perusahaan

Beberapa teori mengenai kebangkrutan perusahaan yang mendukung penelitian ini diantaranya :

2.1.1 Definisi Kebangkrutan

Menurut (Supardi, 2009 dikutip oleh Nafisatin dkk, 2014), kebangkrutan (*bankruptcy*) dapat diartikan sebagai keadaan dimana perusahaan gagal dalam menjalankan operasi perusahaan untuk memperoleh laba. Kebangkrutan juga dapat diartikan sebagai suatu kondisi ketika perusahaan tidak mampu memenuhi kewajibannya kepada kreditor. Sedangkan kesulitan keuangan (*financial distress*) dapat diartikan kondisi yang dekat dengan kebangkrutan ditandai dengan adanya ketidakpastian profitabilitas perusahaan pada masa mendatang (Cahyono, 2013).

Kebangkrutan yang terjadi dapat dilihat dari beberapa indikator. Menurut (Foster, 1986 dikutip oleh Kumalasari, 2014) terdapat beberapa indikator atau sumber informasi mengenai kemungkinan dari kesulitan keuangan :

1. Analisis arus kas untuk periode sekarang dan akan datang.
2. Analisis strategi perusahaan yang mempertimbangkan pesaing potensial, struktur biaya relatif, perluasan rencana dalam industry, kemampuan perusahaan untuk meneruskan kenaikan biaya, kualitas manajemen dan lain sebagainya
3. Analisis laporan keuangan dari perusahaan dan dibandingkan dengan perusahaan lain.
4. Variabel eksternal seperti *returns* sekuritas dan penilaian obligasi.

Pada penelitian ini akan digunakan analisis laporan keuangan dalam memKlasifikasi Status yang terjadi.

2.1.2 Laporan Keuangan

Laporan keuangan perusahaan dibuat dan disusun sesuai dengan aturan atau standar yang berlaku. Hal ini agar laporan keuangan mudah dibaca dan dimengerti, serta mampu menunjukkan kondisi dan posisi keuangan yang sesungguhnya. Laporan keuangan perusahaan dapat digunakan oleh manajemen dan pemilik perusahaan, selain itu juga berguna bagi beberapa pihak luar perusahaan.

Menurut (Kasmir, 2013) bahwa laporan keuangan adalah laporan yang menunjukkan kondisi keuangan perusahaan saat ini atau dalam periode tertentu. Sedangkan menurut (Susilo, 2009 dikutip oleh Maith, 2013) laporan keuangan merupakan hasil akhir dari proses akuntansi yang berisi informasi dan memberikan keterangan-keterangan mengenai data ekonomi perusahaan yang terdiri dari daftar-daftar yang menunjukkan posisi keuangan dan hasil kegiatan perusahaan untuk satu periode yang meliputi neraca, laporan laba rugi dan laporan perubahan keuangan. Laporan keuangan tidak hanya menganalisa laporan masa lalu tetapi juga memklasifikasi kondisi keuangan dimasa depan.

Suatu perusahaan memiliki kewajiban untuk membuat dan melaporkan keuangan perusahaannya dalam periode tertentu. Laporan keuangan menggambarkan pos-pos keuangan perusahaan yang diperoleh dalam suatu periode. Hal yang dilaporkan akan dianalisis agar dapat mengetahui posisi dan kondisi terkini perusahaan, sehingga dapat digunakan untuk menentukan langkah yang dapat diambil perusahaan di masa yang akan datang berdasarkan kekuatan dan kelemahan yang dimiliki (Kasmir, 2013).

2.1.3 Analisis Laporan Keuangan

Setelah menyusun laporan keuangan berdasarkan data yang relevan, serta dilakukan dengan prosedur akuntansi dan penilaian yang benar akan memperlihatkan kondisi keuangan perusahaan yang sesungguhnya. Selanjutnya

laporan keuangan dianalisis dengan tujuan mengetahui posisi keuangan saat ini. Dengan mengetahui posisi keuangan, akan terlihat apakah perusahaan dapat mencapai target yang direncanakan sebelumnya atau tidak. Analisis laporan keuangan perlu dilakukan secara cermat dengan menggunakan metode dan teknik analisis yang tepat, sehingga hasilnya akan tepat pula (Kasmir, 2013).

2.1.4 Rasio Keuangan

Laporan keuangan yang berisi angka-angka yang bernilai mata uang tidak akan bermakna jika tidak dilakukan analisis terhadap informasi yang terkandung didalamnya. Angka-angka tersebut akan bernilai lebih jika dapat dibandingkan antara suatu komponen dengan komponen lainnya. Menurut (Kasmir, 2013) rasio keuangan adalah kegiatan membandingkan angka-angka dengan cara membagi satu angka dengan angka yang lainnya dalam laporan keuangan. Perbandingan dapat dilakukan antara satu komponen dengan komponen lain dalam satu laporan keuangan atau antar komponen diantara laporan keuangan.

Rasio keuangan adalah alat analisis keuangan perusahaan untuk menilai kinerja dari suatu perusahaan berdasarkan perbandingan data keuangan. Penggunaan rasio keuangan dapat menjelaskan penilaian baik dan buruk posisi keuangan pada perusahaan. Dengan begitu dapat dijadikan bahan evaluasi terhadap hal-hal yang perlu dilakukan ke depan agar kinerja perusahaan dapat ditingkatkan atau dipertahankan.

Salah satu teknik analisis rasio keuangan diperkenalkan oleh Altman. Teknik ini menggunakan analisis multiple diskriminan dengan menyusun suatu model untuk memKlasifikasi Status perusahaan, yang mana terbukti sangat akurat mencapai 95% dalam memKlasifikasi Status secara benar. Sehingga analisis rasio keuangan yang dikemukakan oleh Altman dapat digunakan sebagai alat ukur dalam memklasifikasi kebangkrutan.

2.1.5 Analisis Diskriminan Altman

Analisis diskriminan Altman merupakan salah satu teknik statistik yang bisa digunakan untuk memklasifikasi adanya kebangkrutan suatu perusahaan.

Adapun variabel yang digunakan dalam analisis diskriminan Altman adalah (Cahyono, 2013) :

1. Modal Kerja Bersih / Total Aktiva (*Net Working Capital / Total Assets*)

Rasio modal kerja terhadap total aktiva (X1) merupakan rasio aktivitas yang mengukur seberapa besar modal kerja yang ada dapat digunakan untuk membiayai total aktivanya. Modal kerja merupakan investasi perusahaan dalam bentuk aktiva jangka pendek. Modal didefinisikan sebagai aktiva lancar dikurangi kewajiban lancar. Rasio X1 ini dihitung dengan rumus sebagai berikut :

$$X1 = \frac{\text{aset lancar} - \text{kewajiban lancar}}{\text{total aset}} \dots\dots\dots (2.1)$$

Besarnya nilai rasio ini merupakan gambaran seberapa efektif perusahaan menggunakan modal kerja yang tersedia untuk membiayai aktivitas perusahaan dan nilai rasio ini tergantung dari nilai modal kerja dan total aktiva itu sendiri.

2. Laba Ditahan / Total Aktiva (*Retained Earnings / Total Assets*)

Tujuan rasio laba ditahan/total aktiva (X2) adalah profitabilitas yang mengukur akumulasi selama laba perusahaan beroperasi. Rasio X2 ini dihitung dengan rumus sebagai berikut :

$$X2 = \frac{\text{laba ditahan}}{\text{total aset}} \dots\dots\dots (2.2)$$

Saldo laba merupakan bagian ekuitas yang bermakna perusahaan telah menerima/menahan laba dan tidak membayarkannya kepada pemegang saham selama periode tertentu.

3. EBIT / Total Aktiva (*Earning Before Interest and Tax / Total Assets*)

Rasio EBIT/Total aktiva (X3) mengukur kemampuan perusahaan dalam menghasilkan laba dari aktiva yang digunakan. Rasio X3 ini dihitung dengan rumus sebagai berikut :

$$X3 = \frac{\text{EBIT}}{\text{total aset}} \dots\dots\dots (2.3)$$

Laba sebelum bunga dan pajak adalah laba operasional perusahaan sebelum dikenakan pajak dan kebijakan keuangan lainnya.

4. Nilai Pasar Modal Saham / Nilai Buku Utang (*Market Value of Equity / Book Value of Debt*)

Rasio nilai pasar modal/nilai buku utang (X4) mengukur kemampuan pemodal perusahaan dalam menanggung seluruh beban hutangnya. Rasio X4 ini dihitung dengan rumus sebagai berikut :

$$X4 = \frac{\text{total ekuitas}}{\text{kewajiban lancar} + \text{kewajiban tidak lancar}} \dots\dots\dots (2.4)$$

Modal yang dimasukkan adalah gabungan dari nilai pasar dari modal biasa dan nilai pasar dari saham preferen. Nilai buku hutang diperoleh dengan menjumlahkan kewajiban lancar dengan kewajiban jangka panjang.

5. Total Penjualan / Total Aktiva (*Sales/Total Assets*)

Total penjualan/total aktiva (X5) merupakan rasio aktivitas yang mengukur kemampuan manajemen dalam menggunakan aktiva untuk menghasilkan penjualan. Rasio X5 ini dihitung dengan rumus sebagai berikut :

$$X5 = \frac{\text{penjualan}}{\text{total aset}} \dots\dots\dots (2.5)$$

Rasio penjualan terhadap total aktiva menunjukkan efektivitas penggunaan seluruh aktiva perusahaan dalam rangka menghasilkan penjualan bersih.

Menurut (Altman, 1968 dikutip oleh Fitriandini, 2012) bahwa laporan keuangan untuk memKlasifikasi Status sebaiknya tidak lebih dari tiga tahun sebelum terjadinya kebangkrutan. Laporan yang paling baik adalah satu tahun sebelum terjadinya kebangkrutan karena benar-benar menggambarkan keadaan perusahaan sebelum bangkrut.

2.2 Jaringan Syaraf Tiruan

Berikut teori mengenai jaringan syaraf tiruan (JST) yang mendukung penelitian ini diantaranya :

2.2.1 Definisi Jaringan Syaraf Tiruan

Jaring syaraf tiruan (JST) merupakan salah satu cabang dari AI (Artificial Intellegence) atau kecerdasan buatan. Jaringan Syaraf Tiruan merupakan salah satu sistem pemrosesan informasi yang dibentuk menirukan cara kerja otak

manusia dalam menyelesaikan suatu masalah dengan melakukan proses belajar melalui perubahan bobot yang diterimanya. JST mampu melakukan pengenalan kegiatan berbasis data masa lalu atau belajar dari pengalaman. Data masa lalu akan dipelajari oleh jaringan syaraf tiruan sehingga mempunyai kemampuan untuk memberikan keputusan terhadap data yang belum pernah dipelajari (Kiki dan Kusumadewi, 2004).

Jaringan Syaraf Tiruan (JST) atau neural network adalah suatu metode komputasi yang meniru sistem jaringan Syaraf biologis. Metode ini menggunakan elemen perhitungan non-linier dasar yang disebut neuron yang diorganisasikan sebagai jaringan yang saling berhubungan, sehingga mirip dengan jaringan Syaraf manusia. Jaringan Syaraf Tiruan dibentuk untuk memecahkan suatu masalah tertentu seperti pengenalan pola atau klasifikasi karena proses pembelajaran(Yani, Eli. 2005 dikutip oleh Ferri dkk , 2013).

Menurut Hermawan, (2006) dalam kutipan (Alfa, dkk)Jaringan saraf tiruan adalah suatu sistem yang terkomputasi dimana operasi dan arsitektur yang diambil dari pengetahuan tentang sel saraf biologis yang ada di dalam otak, yang merupakan salah satu representasi buatan dari otak manusia yang selalu menstimulasikan proses pembelajaran pada otak manusia tersebut.

Jaringan saraf LVQ (Learning Vector Quantization) adalah suatu metode klasifikasi pola yang masing-masing unit keluaran mewakili kategori atau kelas tertentu. Suatu lapisan kompetitif akan secara otomatis belajar untuk mengklasifikasikan vektor vektor input. Kelas-kelas yang didapatkan sebagai II-2 hasil dari lapisan kompetitif ini hanya tergantung pada jarak antara vektor-vektor input. Jika 2 vektor input mendekati sama, maka lapisan kompetitif akan meletakkan kedua vektor input tersebut ke dalam kelas yang sama. (Rakhmanullah Afif, 2010).

Jaringan Syaraf Tiruan memodelkan jaringan syaraf biologis yang terdapat pada otak manusia. Pemodelan terutama hanya didekati dari sudut kmputasinya saja. JST terdiri dari sejumlah simpul (node) yang merupakan elemen pemroses. Setiap simpul tersebut memodelkan sebuah sel saraf biologis (neuron). Hubungan antar simpul dicapai melalui bobot koneksi (weight). Bobot koneksi menentukan


apakah sinyal yang mengalir bersifat peredam (inhibitory connection). Bobot koneksi yang bersifat meredam dapat dinyatakan, misalnya oleh bilangan negatif, sedangkan yang bersifat merangsang oleh bilangan positif. Selain ditentukan oleh karakteristik bobot koneksinya, besarnya sinyal yang keluar dari sebuah simpul juga ditentukan oleh fungsi aktivasi (activation function) yang digunakannya. Artinya, pemilihan fungsi aktivasi menentukan derajat keaktifan dari sebuah simpul.

2.2.2 Arsitektur Jaringan Syaraf Tiruan

JST memiliki beberapa arsitektur jaringan yang sering digunakan dalam berbagai aplikasi. Arsitektur JST tersebut, antara lain (PuspitaNingrum, 2006) :

1. Jaringan Layer Tunggal (Single Layer Network)

Jaringan dengan lapisan tunggal terdiri dari 1 layer input dan 1 layer output. Setiap neuron/unit yang terdapat di dalam lapisan/layer input selalu terhubung dengan setiap neuron yang terdapat pada layer output. Jaringan ini hanya menerima input kemudian secara langsung akan mengolahnya menjadi output tanpa harus melalui lapisan tersembunyi. Contoh algoritma JST yang menggunakan metode ini yaitu : ADALINE, Hopfield, Perceptron.



Gambar 2.1 Arsitektur Jaringan Syaraf Tiruan Layer Tunggal
(Budianti. E, 2012)

2. Jaringan Banyak Lapisan (Multilayer Net)

Jaringan dengan lapisan jamak memiliki ciri khas tertentu yaitu memiliki 3 klasifikasi layer yakni layer input, layer output, dan juga layer tersembunyi.

Jaringan dengan banyak lapisan ini dapat menyelesaikan permasalahan yang lebih kompleks dibandingkan jaringan dengan lapisan tunggal. Namun, proses pelatihan sering membutuhkan waktu yang cenderung lama. Contoh algoritma Jaringan Syaraf Tiruan yang menggunakan metode ini yaitu : MADALINE, backpropagation, Neocognitron. 3. Jaringan Lapisan Kompetitif (Competitive Layer) Pada jaringan ini sekumpulan neuron bersaing untuk mendapatkan hak menjadi aktif. Contoh algoritma yang menggunakan metode ini adalah LVQ.

2.2.3 Proses Pembelajaran

Fusett (1994) dalam kutipan Puspitaningrum (2006) menjelaskan terdapat dua tipe pembelajaran dalam Jaringan Syaraf Tiruan, yaitu :

1. Pembelajaran terawasi (supervised learning)

Metode pembelajaran pada jaringan syaraf disebut terawasi jika output yang diharapkan telah diketahui sebelumnya. Maksudnya, sejak awal pembelajaran, output telah ditetapkan terlebih dahulu, dengan nama lainnya adalah target. Perbedaan antara output-output aktual dengan output-output yang diinginkan digunakan untuk mengoreksi bobot jaringan syaraf tiruan agar jaringan syaraf tiruan dapat menghasilkan jawaban sedekat (semirip) mungkin dengan jawaban yang benar yang telah diketahui oleh jaringan syaraf. Terdapat berbagai tipe pembelajaran terawasi beberapa diantaranya Hebb Rule, Perceptron, Delta Rule, Backpropagation, Heteroassociative Memory, Bidirectional Associative Memory (BAM), Learning Vektor Quantization (LVQ).

2. Pembelajaran tak terawasi (unsupervised learning)


Pembelajaran tak terawasi tidak memerlukan target output. Hasil yang seperti apakah yang diharapkan selama proses pembelajaran, pada metode ini tidak dapat ditentukan. Selama proses pembelajaran, nilai bobot disusun dalam suatu range tertentu tergantung pada nilai input yang diberikan. Tujuan pembelajaran ini adalah mengelompokkan unit-unit yang hampir sama dengan II-6 suatu area tertentu. Pembelajaran ini biasanya sangat cocok untuk

pengelompokan (klasifikasi) pola. Contoh metode pembelajaran tak terawasi adalah jaringan kohonen (kohonen network).

2.3 Learning Vector Quantization (LVQ)

Jaringan LVQ (*Learning Vector Quantization*) juga diperkenalkan oleh Tuevo Kohonen. LVQ adalah salah satu jaringan saraf tiruan yang melakukan pembelajaran secara terawasi. LVQ mengklasifikasikan input secara berkelompok ke dalam kelas yang sudah didefinisikan melalui jaringan yang telah dilatih. Dengan kata lain LVQ mendapatkan n *input* dan mengelompokkan kedalam m *output*.

Learning Vector Quantization (LVQ) merupakan suatu metode untuk melakukan pelatihan terhadap lapisan-lapisan kompetitif yang terawasi. Lapisan kompetitif akan belajar secara otomatis untuk melakukan klasifikasi terhadap vektor *input* yang memiliki diberikan. Apabila beberapa vektor *input* memiliki jarak yang sangat berdekatan, maka vektor-vektor *input* tersebut akan dikelompokkan dalam kelas yang sama. Pemrosesan yang terjadi pada setiap neuron adalah mencari jarak antara suatu vektor *input* ke bobot yang bersangkutan (w_1 dan w_2), w_1 adalah vektor bobot yang menghubungkan setiap neuron pada lapisan *input* ke neuron pertama pada lapisan *output*, sedangkan w_2 adalah vektor bobot yang menghubungkan setiap neuron pada lapisan *input* ke neuron kedua pada lapisan *output* (Kusumadewi, 2004). Fungsi aktivasi linear, $y=x$.



Gambar 2.2 Arsitektur *Learning Vector Quantization* (Kusumadewi, 2004)

2.3.1 Algoritma LVQ 1

Pemrosesan yang terjadi pada setiap neuron adalah mencari jarak antara suatu vektor input ke bobot yang bersangkutan (w_1 dan w_2). w_1 adalah vektor bobot yang menghubungkan setiap neuron pada lapisan input ke neuron pertama pada lapisan output, sedangkan w_2 adalah vektor bobot yang menghubungkan setiap neuron pada lapisan input ke neuron kedua lapisan output. Fungsi aktivasi F_1 akan memetakan y_{in1} ke $y_1 = 1$ apabila $\|x - w_1\| < \|x - w_2\|$, dan $y_1 = 0$ jika sebaliknya. Demikian pula dengan yang terjadi pada fungsi aktivasi F_2 , akan memetakan y_{in2} ke $y_2 = 1$ apabila $\|x - w_2\| < \|x - w_1\|$, dan $y_2 = 0$ jika sebaliknya $\|x - w_2\| > \|x - w_1\|$.

Algoritma LVQ (Kusumadewi, 2002 dikutip oleh Amanu Ramadana, dkk 2004):

1. Tetapkan: Bobot (W), Maksimum Epoch (MaxEpoch) error minimum yang diharapkan (Eps), learning rate (α)
2. Masukkan :
 - a. Data input : $x(m,n)$
 - b. Target berupa kelas : $T(l,n)$
3. Terapkan kondisi awal:
 - a. Epoch = 0;

b. Err = 1.

4. Kerjakan selama : (epoh < MaxEpoh) dan (α > Eps)

a. Epoh = epoh+1;

b. Kerjakan untuk i= 1 sampai n

i. Memilih (J) jarak sedemikian hingga $\|X-W_j\|$ minimum (sebut sebagai Cj) atau $D1 = \epsilon - \dots\dots\dots(2.1)$

ii. Perbaiki Wj dengan ketentuan: - Jika $T = C_j$ maka : - $W_j(\text{baru}) = W_j(\text{lama}) + \alpha (x - W_j(\text{lama})) \dots\dots\dots(2.2)$ - Jika $C_j \neq T$ maka : $W_j(\text{baru}) = W_j(\text{lama}) - \alpha (X - W_j(\text{lama}))$

c. Kurangi nilai α

Setelah dilakukan pelatihan, akan diperoleh bobot-bobot akhir (W). Bobot-bobot ini nantinya akan digunakan untuk melakukan simulasi atau pengujian. Misalkan dilakukan pengujian terhadap np buah data. Maka algoritma pengujiannya adalah:

1. Masukkan data yang akan diuji, misal X_{ij} dengan $i = 1, 2, \dots, np$ dan $j = 1, 2, \dots, m$.
2. Kerjakan untuk $i=1$ hingga np
 - a. Tentukan J sedemikian hingga $\|X_{ij}-W_{ij}\|$ minimum
 - b. J adalah kelas untuk X_i

2.3.2 Variasi Algoritma LVQ

Menurut Kohonen (1990a, 1990b) dikutip oleh Fausett (1994) terdapat beberapa variasi dari algoritma LVQ dasar (LVQ1) yaitu, LVQ2, LVQ2.1, dan LVQ3. Karakteristik pada algoritma LVQ1 adalah hanya vektor referensi terdekat (vektor pemenang) dengan vektor masukan yang diperbaharui. Arah perpindahan vektor tergantung pada apakah vektor referensi memiliki kelas yang sama dengan vektor masukan.

Algoritma LVQ yang telah ditingkatkan, vektor pemenang dan vektor runner up akan sama-sama belajar bila kondisi tertentu terpenuhi. Idennya adalah bila jarak antara vektor masukan dengan vektor pemenang dan vektor runner up kira-kira mempunyai jarak yang sama.

2.4 Learning Vector Quantization lanjutan (LVQ2.1)

LVQ 2.1, diusulkan oleh Kohonen, bertujuan untuk pemisahan yang efisien antara prototipe kelas yang berbeda dan telah terbukti memberikan yang baik hasil klasifikasi (Kohonen, 1990; Pusat Penelitian Jaringan Syaraf Tiruan, 2002). Dengan contoh ξ^μ , dua prototipe terdekat w_S dan w_T diperbarui jika kondisi berikut terpenuhi: (1) kelas c_S dan c_T berbeda, dan (2) c_S atau c_T sama dengan y^μ . Prototipe dengan kelas yang benar dipindahkan ke arah data, sementara yang lainnya dipindahkan lebih jauh lagi $f_S = 1$, $f_T = -1$ jika $c_S = y^\mu$; $f_S = -1$, $f_T = +1$ lagi.

Sudah diketahui bahwa aturan belajar memiliki masalah stabilitas yang tidak seimbang kumpulan data, menghasilkan prototipe divergen yang memburuk kinerja (Kohonen, 1990). Hal ini disebabkan karena aturan pembaruan pada contoh ξ^μ , $\left(\frac{d_T^\mu}{d_S^\mu}, \frac{d_S^\mu}{d_T^\mu} \right)$ adalah di sekitar $\rho = \frac{1 - \omega}{1 + \omega}$, dengan ω adalah parameter jendela, $0 < \omega \leq 1$ dan oleh karena itu $1 > \rho \geq 0$. Namun, jendela ini tidak efektif untuk data berdimensi sangat tinggi, seperti yang kita dapatkan $\lim_{N \rightarrow \infty} (\xi^\mu - w_S)^2 \approx (\xi^\mu)^2$ karena $(\xi^\mu)^2 = O(N)$ mendominasi yang lain $O(1)$ -terms, $(w_S \cdot \xi^\mu)$ dan (w_S^2) . Akibatnya, definisi jendela ini tidak tidak bekerja dalam dimensi yang sangat tinggi, dibuktikan oleh

$$\lim_{N \rightarrow \infty} \min \left(\frac{(\xi^\mu - w_T^{\mu-1})^2}{(\xi^\mu - w_S^{\mu-1})^2}, \frac{(\xi^\mu - w_S^{\mu-1})^2}{(\xi^\mu - w_T^{\mu-1})^2} \right) = 1 \quad \dots\dots\dots 2.6)$$

yang menyiratkan bahwa setiap contoh jatuh ke jendela. Oleh karena itu, di Berikut, kami menerapkan batasannya

$$|(\xi^\mu - w_T)^2 - (\xi^\mu - w_S)^2| \leq k \min((\xi^\mu - w_S)^2, (\xi^\mu - w_T)^2) \quad \dots\dots\dots (2.7)$$

dimana k adalah bilangan positif kecil. Perhatikan bahwa istilah $(\xi^\mu)^2 = O(N)$ membatalkan keluar di sisi kiri, sementara itu mendominasi di sisi kanan $N \rightarrow \infty$. Dengan demikian, sisi kanan menjadi $k \cdot (\xi^\mu)^2$, dan kondisinya nontrivial hanya jika $k = O(1/N)$. Kami memperkenalkan parameter jendela rescaled $\delta = k \cdot (\xi^\mu)^2 = O(1)$ sehingga skema jendela adalah $-\delta \leq (d_T^\mu - d_S^\mu) \leq \delta$; δ adalah positif. Kami menggambarkan peraturan ini sebagai fungsi modulasi berikut,

$$f_S = \chi(c_S, y_\sigma^\mu) \sum_{T: c_T \neq c_S} (\Theta_{ST}^{-\delta} - \Theta_{ST}^{+\delta}) \prod_{U \neq S, T} \Theta_{SU} \Theta_{TU} \dots$$

(2.8)

dengan $\chi(c_S, y_\sigma^\mu) = 1$ jika $c_S = y_\sigma^\mu$ dan $\chi(c_S, y_\sigma^\mu) = -1$ lainnya. Kami menggunakan singkatan notasi $\delta_{ji} \equiv (d_{\mu i} - d_{\mu j} - \delta)$ dan $j_i \equiv 0_{ji} = (d_{\mu i} - d_{\mu j})$, dimana (x) adalah fungsi Heaviside $(x) = 1$ jika $x > 0$; 0 lainnya Kami menyimpulkan prototipe $\{w_T | c_T = c_S\}$, dan istilah $(-\delta_{ST} - +\delta_{ST}) = (d_{\mu T} - d_{\mu S} + \delta) - (d_{\mu T} - d_{\mu S} - \delta)$ memberlakukan kondisi window. Istilah produk $U = S, T$ $SU TU$ mengeluarkan contoh di mana w_S dan w_T adalah dua yang paling dekat prototip Bentuk f_S ini memungkinkan untuk analisis yang diberikan pada bagian 4.

2.5 Normalisasi

Normalisasi adalah proses transformasi nilai menjadi kisaran 0 dan 1 (Teknomo, 2006 dalam Elvia Budianita, 2013). Normalisasi ini merupakan proses penskalaan nilai atribut dari data sehingga bisa jatuh pada range tertentu. Pada perhitungan jarak euclidean, atribut berskala panjang dapat mempunyai pengaruh lebih besar daripada atribut berskala pendek. Oleh karena itu, untuk mencegah hal tersebut perlu dilakukan normalisasi terhadap nilai atribut. Normalisasi ini terbagi menjadi 5 klasifikasi metode pencariannya, yakni : min-max, z-score, decimal scaling, sigmoidal, dan softmax. Z-score merupakan metode normalisasi yang berdasarkan mean (nilai rata-rata) dan standard deviation (deviasi standar) dari data. Dibawah ini merupakan rumus dari z-score :

$$\text{newdata} = (\text{data} - \text{mean}) / \text{std} \dots \dots \dots$$

(2.9)

Metode ini sangat berguna jika kita tidak mengetahui nilai actual minimum dan maksimum dari data.

Sedangkan metode normalisasi Decimal scaling ini, melakukan normalisasi dengan menggerakkan nilai decimal dari data ke arah yang diinginkan. Berikut rumus dari decimal scaling :

$$\text{newdata} = \text{data} / 10^i \quad \dots\dots\dots (2.10)$$

Dimana i adalah nilai integer untuk menggerakkan nilai decimal ke arah yang diinginkan.

Metode selanjutnya adalah Sigmoidal Normalization yakni, melakukan normalisasi data secara nonlinier ke dalam range -1-1 dengan menggunakan fungsi sigmoid. Berikut rumus dari metode ini adalah :

$$\text{newdata} = (1 - e^{(-x)}) / (1 + e^{(-x)}) \quad \dots\dots\dots (2.11)$$

dimana:

$$x = (\text{data} - \text{mean}) / \text{std}$$

e = nilai eksponensial (2,718281828)

Metode ini sangat berguna pada saat data-data yang ada melibatkan data-data outlier.

Berikutnya metode Softmax, metode ini merupakan pengembangan transformasi secara linier. Output rangenya adalah 0-1. Berikut adalah rumus dari metode ini :

$$\text{newdata} = 1 / (1 + e^{(-\text{transfdata})}) \quad \dots\dots\dots (2.12)$$

dimana:

$$\text{transfdata} = (\text{data} - \text{mean}) / (x * (\text{std} / (2 * 3.14)))$$

x = respon linier di deviasi standar

Metode yang terakhir adalah Min-Max, merupakan metode normalisasi dengan melakukan transformasi linier terhadap data asli. Formula untuk normalisasi atribut X adalah:

$$X = \frac{X - \min(X)}{\text{Max}(X) - \min(X)} \quad \dots\dots\dots (2.13)$$

dengan,

X^* adalah nilai setelah dinormalisasi,

X adalah nilai sebelum dinormalisasi,

$\min(X)$ adalah nilai minimum dari fitur, dan

$\max(X)$ adalah nilai maksimum dari suatu fitur

Keuntungan dari metode ini adalah keseimbangan nilai perbandingan antar data saat sebelum dan sesudah proses normalisasi. Tidak ada data bias yang dihasilkan oleh metode ini. Kekurangannya adalah jika ada data baru, metode ini akan memungkinkan terjebak “out of bound” error. Namun dari ke-5 metode tersebut, penulis memilih menggunakan metode normalisasi Min-Max, karena selain dalam data diketahui nilai minimum dan maksimumnya, min-max ini sudah banyak digunakan para peneliti lainnya untuk melakukan normalisasi, karena min-max tergolong mudah dan hasil yang dapat adalah tidak bias sehingga mempermudah pengerjaan penormalisasian data dan lebih efisien.

Teknomo (2006) dalam Elvia Budianita (2013) juga menjelaskan tentang penilaian dan rank adalah variabel ordinal yang dapat diubah menjadi variabel kuantitatif melalui normalisasi. Suharto (2008) dalam Elvia Budianita (2013) menjelaskan bahwa data ordinal merupakan data yang memiliki peringkat atau urutan. Angka yang diberikan mengandung tingkatan dan digunakan untuk mengurutkan objek dari yang paling rendah sampai yang paling tinggi, atau sebaliknya. Misalnya, jawaban pertanyaan tentang kecenderungan masyarakat untuk menghadiri rapat umum pemilihan kepala daerah, mulai dari tidak pernah absen menghadiri dengan kode 5, kadang-kadang saja menghadiri dengan kode 4, kurang menghadiri dengan kode 3, tidak pernah menghadiri dengan kode 2 hingga tidak ingin menghadiri sama sekali dengan kode 1.

Teknomo (2006) dalam Elvia Budianita (2013) selanjutnya menjelaskan, setelah jajaran dinormalisasi, jarak dapat dihitung sebagai variabel kuantitatif. Jarak antara dua benda yang diwakili oleh variabel ordinal dapat ditentukan II-16 dengan mengubah skala ordinal ke skala rasio dengan melakukan langkah-langkah berikut:

1. Mengkonversi nilai ordinal ke rank ($r = 1$ hingga R).
2. Normalisasi peringkat ke nilai standar dari nol sampai satu $[0,1]$ dengan persamaan:

$$X = \frac{T - 1}{R - 1} \dots\dots\dots (2.14)$$
3. Jarak dapat dihitung dengan memperlakukan nilai ordinal sebagai variabel kuantitatif (diantaranya dapat menggunakan persamaan jarak euclidean, city blok, chebyshev, minkowski, canberra, sudut pemisahan, dan koefisien korelasi).

2.6 Akurasi

Akurasi adalah kunci dalam pembuatan sebuah aplikasi. Performa dari suatu model dapat diukur dengan tingkat akurasinya berdasarkan *Confusion matrix*. Sebuah sistem yang melakukan klasifikasi diharapkan dapat melakukan klasifikasi semua himpunan data dengan benar, tetapi tidak dipungkiri bahwa kinerja suatu sistem tidak bisa 100% benar sehingga sebuah sistem klasifikasi harus diukur tingkat ketepatan klasifikasinya menggunakan matriks konfusi (Gaussian, 2015). Tabel 2.1 adalah contoh dari *confusion matrix*.

Tabel 2.1 Confusion Matrix

Fij		Kelas Hasil prediksi (j)		
		Kelas = 1	Kelas = 2	Kelas = 3
Kelas Asli (i)	Kelas = 1	f11	f12	f13
	Kelas = 2	f21	f22	f23
	Kelas = 3	f31	f32	f33

Akurasi merupakan persentase dari data yang diklasifikasi secara benar. Perhitungan akurasi adalah :

$$\text{Akurasi} = \frac{(f11 + f22 + f33)}{(f11+f12+f13)+(f21+f22+f23)+(f31+f32+f33)} \dots\dots\dots(2.15)$$

atau

$$\text{Akurasi} = \frac{\text{Jumlah data yang diklasifikasi secara benar}}{\text{Jumlah data yang diklasifikasi yang dilakukan}}$$

Keterangan :

F11 : *True positives* kelas 1, merupakan jumlah data dengan kelas 1 yang diklasifikasikan positif kelas 1.

F12 : *False positives* kelas 1, merupakan jumlah data dengan kelas 2 yang diklasifikasikan positif kelas 1.

F13 : *False positives* kelas 1, merupakan jumlah data dengan kelas 3 yang diklasifikasikan positif kelas 1.

F21 : *False positives* kelas 2, merupakan jumlah data dengan kelas 1 yang diklasifikasikan positif kelas 2.

F22 : *True positives* kelas 2, merupakan jumlah data dengan kelas 2 yang diklasifikasikan positif kelas 2.

F23 : *False positives* kelas 2, merupakan jumlah data dengan kelas 3 yang diklasifikasikan positif kelas 2.

F31 : *False positives* kelas 3, merupakan jumlah data dengan kelas 1 yang diklasifikasikan positif kelas 3.

F32 : *False positives* kelas 3, merupakan jumlah data dengan kelas 1 yang diklasifikasikan positif kelas 3.

F33 : *True positives* kelas 3, merupakan jumlah data dengan kelas 3 yang diklasifikasikan positif kelas 3.

2.7 Kajian Pustaka

Beberapa penelitian terkait dengan penelitian ini akan dijelaskan dalam bentuk tabel 2.2 di bawah ini.

Tabel 2.2 Kajian Pustaka

No	Penulis	Tahun	Judul	Metode	Hasil
1	Cynthia Gustikaningty as Yedanti	2010	Klasifikasi Status Perusahaan	<i>Backpropagation</i>	algoritma <i>Backpropagation</i> mampu

Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:

- Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
- Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.

2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

No	Penulis	Tahun	Judul	Metode	Hasil
	Putri		Menggunakan <i>Artificial Neural Network</i>		memKlasifikasi Status perusahaan akibat kesulitan keuangan dengan tingkat keakuratan mencapai 80%
2	Angga Rizky Pura	2015	Klasifikasi Status Perusahaan Menggunakan Metode <i>Naïve Bayes Classifier</i>	<i>Naïve Bayes</i>	klasifikasi perusahaan bangkrut, kurang sehat dan sehat yang dijadikan model untuk Klasifikasi Status dengan tingkat keakuratan tertinggi mencapai 89 %
3	Hidayatul Fitri	2015	Penerapan Modifikasi Learning Vector Quantization Lanjutan (LVQ 2.1) untuk klasifikasi status gizi balita	<i>LVQ 2.1</i>	Dengan algortima <i>LVQ 2.1</i> didapatkan klasifikasi status gizi balita diperoleh tingkat akurasi sistem sebesar 91,7 %

Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:

a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.

b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.

2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

No	Penulis	Tahun	Judul	Metode	Hasil
4	A. W. Witoelar	2010	<i>Window-Based Example Selection in Learning Vector Quantization</i>	<i>LVQ 2.1, GLVQ, LFM dan RSLVQ</i>	<i>prototipe LVQ 2.1</i> menghasilkan hasil paling optimal dari metode lain
5	Fitriandini	2012	Klasifikasi Status perusahaan menggunakan <i>Support Vector Machine (SVM)</i>	<i>SVM</i>	Fungsi kernel RBF didapat parameter terbaik $C=1$ dan $\text{Gamma}=4$ dengan tingkat keakuratan klasifikasi tertinggi mencapai 90,78 %

Berdasarkan penelitian di atas terlihat penggunaan metode klasifikasi mendapatkan tingkat akurasi yang lebih baik daripada Metode *Artificial Neural Network*. Sehingga pada penelitian ini akan mencoba menggabungkan Metode *Artificial Neural Network* yang berbasis klasifikasi dalam mengklasifikasikan kondisi suatu perusahaan.